



# Journal of Informatics and Telecommunication Engineering

Sekretariat : Universitas Medan Area, Gedung Fakultas Teknik, Program Studi Informatika

Alamat : Jalan Kolam Nomor 1 Medan Estate/Jalan PBSI Nomor 1

E-mail : jite@uma.ac.id

Ref : 014/UMA/JITE/IV/2025

Medan, 21 April 2025

Subject : Letter of Acceptance

To :

Mr./Mrs. **William Gultom**

Assalamu'alaikum Wr. Wb

We would like to express our sincere gratitude for your participation in submitting an article to the Journal of Informatics and Telecommunication Engineering (JITE). We hereby inform you that the article listed below:

**Paper : Enhancing Brain Tumor Disease Classification via SqueezeNet Architecture Integrated with Group Convolution**

**Author : William Gultom**

Based on the review results, we are pleased to inform you that your submitted article has been ACCEPTED for publication in JITE Journal - **Special Issues 2025: Innovations in Predictive Analytics and Sentiment Analysis - Applications in Education, Healthcare, and Social Media**, ISSN: 2549-6247 (Print) ISSN: 2549-6255 (Online).

We would like to thank you for your attention and cooperation.

Wassalamu'alaikum, Wr.Wb.





# JITE (*Journal of Informatics and Telecommunication Engineering*)

Available online <http://ojs.uma.ac.id/index.php/jite> DOI : 10.31289/jite.vxix.xxx

Received: dd-mm-yyyy

Accepted: dd-mm-yyyy

Published: dd-mm-yyyy

## **Enhancing Brain Tumor Disease Classification via SqueezeNet Architecture Integrated with Group Convolution**

**William Gultom<sup>1)</sup>, Muhathir<sup>2)</sup>**

1)Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

2) Teknik Informatika, Fakultas Teknik, Universitas Medan Area, Indonesia

\*Corresponding Email:

### **Abstrak**

Klasifikasi tumor otak berbasis citra MRI merupakan tantangan signifikan dalam pengolahan citra medis, terutama ketika menghadapi ketidakseimbangan jumlah data antar kelas. Ketimpangan ini dapat menyebabkan model bias terhadap kelas mayoritas dan menurunkan sensitivitas terhadap kelas minoritas, yaitu pasien dengan tumor. Penelitian ini bertujuan untuk menganalisis pengaruh penerapan teknik *Group Convolution* pada arsitektur VGG19 dan SqueezeNet dalam meningkatkan efisiensi dan akurasi klasifikasi tumor otak. Penelitian menggunakan pendekatan kuantitatif eksperimental dengan implementasi *Convolutional Neural Network* (CNN) berbasis PyTorch. Dataset yang digunakan terdiri dari dua kelas, "Yes" (dengan tumor) dan "No" (tanpa tumor), yang dibagi ke dalam folder Train, Validation, dan Test. Model diuji dengan membandingkan performa antara arsitektur standar dan versi modifikasi yang mengintegrasikan *Group Convolution*. Hasil eksperimen menunjukkan bahwa SqueezeNet dengan *Group Convolution* berhasil mencapai akurasi hingga 90%, lebih tinggi dibandingkan model orisinal. Selain itu, sensitivitas terhadap kelas minoritas meningkat secara signifikan, menunjukkan kemampuan model dalam menangani data tidak seimbang. Temuan ini mengindikasikan bahwa *Group Convolution* dapat meningkatkan efisiensi komputasi sekaligus memperbaiki performa klasifikasi. Dengan demikian, teknik ini relevan untuk pengembangan sistem diagnosis otomatis. Penelitian selanjutnya disarankan menggabungkan pendekatan ini dengan metode seperti *attention mechanism* untuk hasil klasifikasi yang lebih optimal dan andal.

**Kata Kunci:** Klasifikasi Tumor Otak, MRI, CNN, SqueezeNet, Group Convolution.

### **Abstract**

*Brain tumor classification using MRI images is a major challenge in medical image processing, particularly when facing imbalanced data between classes. This imbalance often leads to model bias toward the majority class and reduces sensitivity to the minority class—patients with tumors. This study aims to analyze the impact of applying Group Convolution techniques to the VGG19 and SqueezeNet architectures to enhance both computational efficiency and classification accuracy. A quantitative experimental approach was employed, implementing Convolutional Neural Networks (CNNs) using the PyTorch framework. The dataset includes two classes, "Yes" (with tumor) and "No" (without tumor), organized into Train, Validation, and Test folders. The models were evaluated by comparing the performance of standard architectures with modified versions integrating Group Convolution. Experimental results show that SqueezeNet with Group Convolution achieved up to 90% accuracy, outperforming the original model. Additionally, the model exhibited significantly improved sensitivity to the minority class, indicating better performance under imbalanced conditions. These findings suggest that Group Convolution enhances not only computational efficiency but also classification capability. Therefore, this technique is applicable in developing automated diagnostic systems. Future research is encouraged to combine Group Convolution with methods such as attention mechanisms to achieve more optimal and reliable classification results.*

**Keywords:** Brain Tumor Classification, MRI, CNN, SqueezeNet, Group Convolution.

**How to Cite:** Pertama, N.P. Pertama, P. & Ketiga, P. (2021). Judul Hendaknya Ringkas dan Informatif Tidak Lebih dari 15 Kata. *JITE (Journal Of Informatics And Telecommunication Engineering)*. 4 (2): 1-10

## I. PENDAHULUAN

Klasifikasi penyakit tumor otak merupakan salah satu tantangan dalam bidang medis dan kecerdasan buatan yang membutuhkan pendekatan yang akurat dan efisien (Thaariq et al., 2024). Tumor merupakan suatu kondisi yang ditandai oleh pertumbuhan sel-sel tubuh yang abnormal dan tidak terkendali, yang dapat berkembang diberbagai organ manusia, termasuk otak (Aamir et al., 2022). Tumor otak merupakan kelainan yang dapat bersifat jinak maupun ganas, dan diagnosis dini sangat penting untuk menentukan langkah pengobatan yang tepat. Dalam beberapa tahun terakhir, metode deep learning telah digunakan secara luas dalam analisis citra medis, termasuk dalam klasifikasi tumor otak (Simanjorang et al., 2025). Tumor di otak bisa dideteksi melalui pemeriksaan *Magnetic Resonance Imaging* (MRI), yang menggunakan alat medis khusus (Febrianti et al., 2020). Jika tidak didiagnosis dengan cepat dan akurat, tumor otak dapat menyebabkan dampak yang fatal (Ekong et al., 2022).

Salah satu arsitektur deep learning yang banyak digunakan untuk tugas klasifikasi adalah SqueezeNet (Situmorang & Asri, 2024). SqueezeNet dikenal karena ukurannya yang kecil namun tetap memiliki performa yang kompetitif dibandingkan dengan model yang lebih besar (Ayu & Pradipta, 2024). Arsitektur ini menggunakan konsep Fire Module yang menggabungkan lapisan SqueezeNet dan Expand untuk mengurangi jumlah parameter dan meningkatkan efisiensi komputasi (Hao et al., 2024).

SqueezeNet dikembangkan oleh Parmonangan R Togatorop dan Ahmad Fauzi (Togatorop & Fauzi, 2022). Model ini dirancang dengan tujuan menghasilkan arsitektur jaringan saraf konvolusi yang lebih ringan tanpa kehilangan akurasi yang signifikan dibandingkan dengan model yang lebih besar seperti AlexNet (Ningrum et al., 2024).

Dalam bidang medis, SqueezeNet telah digunakan untuk mendeteksi dan mengklasifikasikan berbagai penyakit berbasis citra, seperti tumor otak, kanker kulit, dan penyakit paru-paru (Sa'idah et al., 2022). Selain itu, SqueezeNet juga diterapkan dalam sistem pengawasan berbasis visi komputer untuk mendeteksi objek dengan efisiensi komputasi yang tinggi (Putri et al., 2024). Di bidang kendaraan otonom, model ini digunakan dalam sistem pengenalan rambu lalu lintas dan navigasi berbasis citra (Jeri & Hidayat, 2024). Machine learning adalah gabungan dari berbagai teknik dan pendekatan yang digunakan untuk mengembangkan algoritma guna mendukung proses prediksi, klasifikasi, serta identifikasi pola (Gupta, 2022).

Namun, meskipun SqueezeNet memiliki keunggulan dalam ukuran dan efisiensi, ada peluang untuk meningkatkan performanya dengan menambahkan teknik Group Convolution (Pangestu et al., 2024). Group Convolution memungkinkan pemisahan filter konvolusi ke dalam beberapa grup, yang dapat mengurangi jumlah parameter lebih lanjut dan meningkatkan efisiensi komputasi tanpa mengorbankan akurasi secara signifikan (Su et al., 2020).

SqueezeNet memilih untuk menggunakan Group Convolution karena teknik ini dapat mengurangi jumlah parameter dan komputasi tanpa mengorbankan akurasi secara signifikan (Lyu et al., 2024). Matriks dioptimalkan dengan cara mengelompokkan lima pola yang serupa kedalam satu grup, sehingga jumlah elemen yang tidak perlu dalam matriks berkurang. Pola-pola lain yang berbeda kemudian dikelompokkan ke dalam grup-grup berikutnya (Jose et al., 2022). Dengan membagi filter konvolusi ke dalam beberapa grup, Group Convolution memungkinkan efisiensi yang lebih tinggi dalam proses pelatihan dan inferensi, menjadikannya solusi yang ideal untuk model yang berfokus pada efisiensi seperti SqueezeNet (Wang et al., 2019).

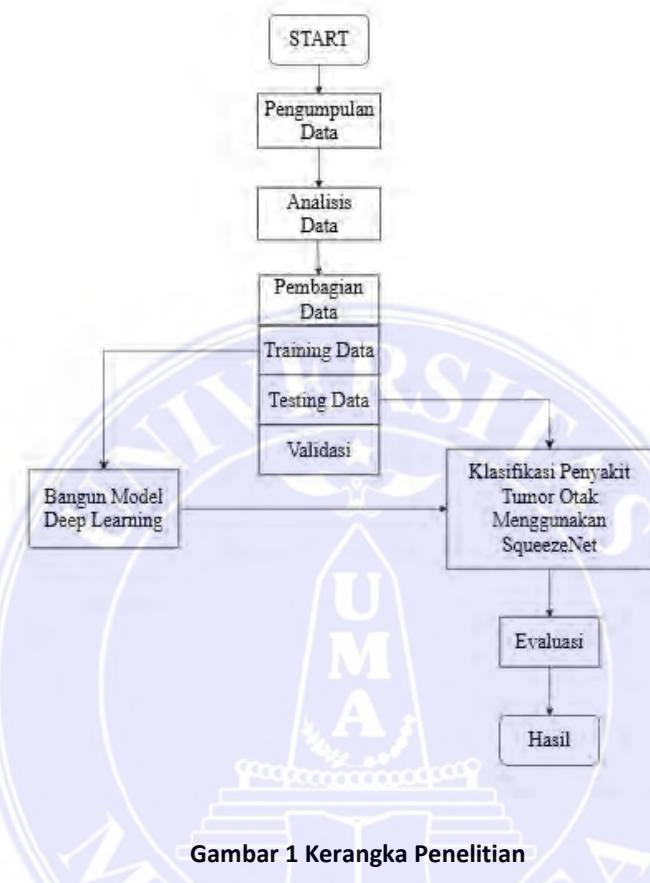
Group Convolution telah banyak diteliti sebelumnya dan diterapkan pada berbagai metode deep learning lainnya. Contohnya, pada arsitektur ResNet, penggunaan Group Convolution terbukti meningkatkan akurasi dalam tugas klasifikasi citra dengan kompleksitas yang lebih rendah dibandingkan dengan ResNet. Studi lain menunjukkan bahwa penggunaan Group Convolution dalam DenseNet dan ShuffleNet mampu meningkatkan performa dalam pengenalan objek dan segmentasi citra medis dengan akurasi yang tinggi. Selain itu, model berbasis Group Convolution yang diimplementasikan dalam klasifikasi tumor otak menggunakan MRI 3D menunjukkan peningkatan akurasi hingga 90%, dibandingkan dengan metode konvolusi standar yang hanya mencapai 67% (Agrawal et al., 2022).

Berdasarkan keunggulan SqueezeNet dan ketangguhan model Group Convolution maka dalam penelitian ini akan menguji coba menyisipkan Group Convolution kedalam SqueezeNet untuk mengklasifikasi penyakit tumor otak.

## II. Metode Penelitian

### A. Kerangka Penelitian

Pada analisis arsitektur SqueezeNet untuk klasifikasi penyakit tumor otak, akan disusun beberapa tahapan dalam bentuk diagram alur untuk mempermudah penyusunan penelitian ini dapat dilihat dari gambar berikut ini :



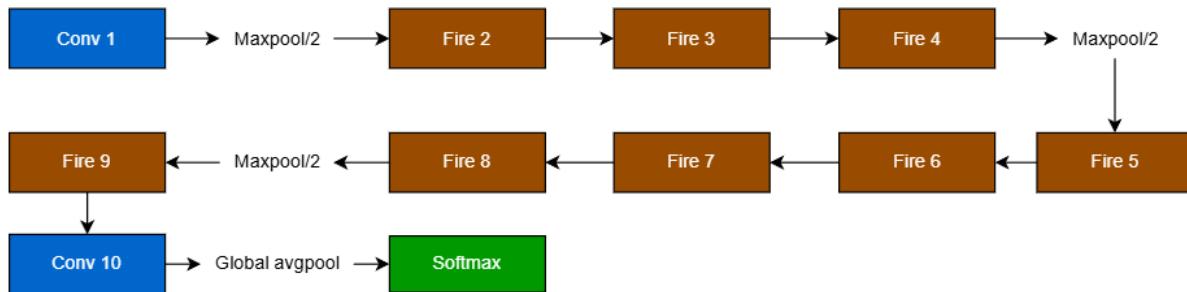
### B. Jenis dan Sumber data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh secara tidak langsung, yaitu dari sumber yang sudah ada. Dalam penelitian ini, data sekunder yang berupa citra atau gambar diambil dari sumber terbuka <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection>. Pada situs tersebut terdapat dua kelas jenis penyakit tumor otak yang digunakan, yaitu Terinfeksi dan Normal. Penelitian ini menggunakan 3000 gambar tumor otak sebagai data, yang dibagi menjadi tiga bagian yaitu data training, data testing, dan data validasi. Sampel gambar tumor otak tersebut terdiri dari 80% data training, 10% data testing, dan 10% data validasi.

**Table 1 Pembagian Dataset**

No	Kelas	Dataset		
		Training (80%)	Testing (10%)	Validasi (10%)
1	Terinfeksi	1200	150	150
2	Normal	1200	150	150

### C. Arsitektur SqueezeNet

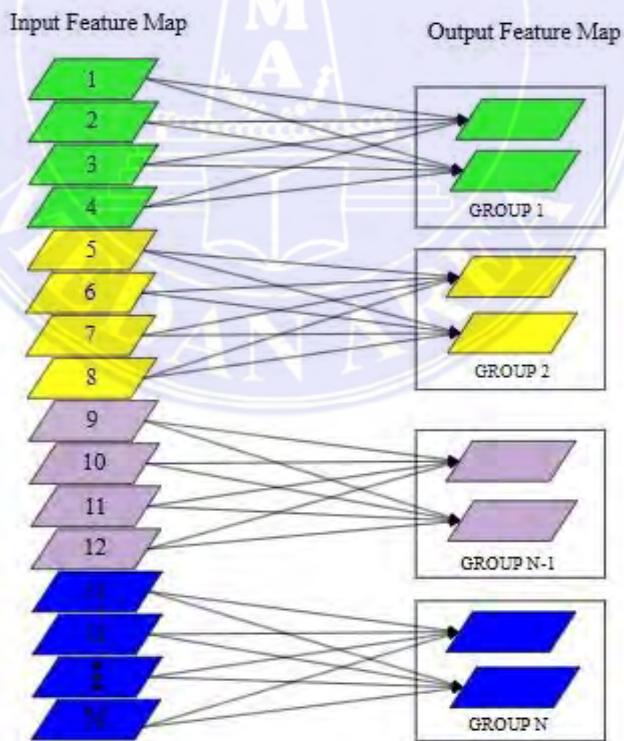


**Gambar 2 Arsitektur SqueezeNet**

Gambar ini menggambarkan arsitektur SqueezeNet, sebuah model jaringan saraf konvolusional (CNN) yang dirancang untuk meningkatkan efisiensi komputasi dengan jumlah parameter yang lebih sedikit dibandingkan model konvensional. Struktur jaringan ini diawali dengan lapisan konvolusi pertama (Conv1), kemudian dilanjutkan dengan serangkaian Fire module. Setiap Fire module terdiri dari lapisan squeeze (konvolusi  $1 \times 1$ ) dan expand (kombinasi konvolusi  $1 \times 1$  dan  $3 \times 3$ ) yang berfungsi untuk mengurangi parameter tanpa mengorbankan kualitas representasi fitur (H. Harahap et al., 2024).

Setelah beberapa blok Fire module, diterapkan operasi max pooling guna mengecilkan dimensi fitur. Model ini diakhiri dengan lapisan konvolusi (Conv10), diikuti oleh global average pooling dan lapisan softmax untuk menentukan kelas keluaran. Dengan rancangan ini, SqueezeNet mampu mencapai kinerja klasifikasi yang tetap kompetitif meskipun memiliki ukuran model yang lebih kecil, sehingga cocok untuk diterapkan pada perangkat dengan keterbatasan sumber daya komputasi.

### D. Arsitektur Group Convolution

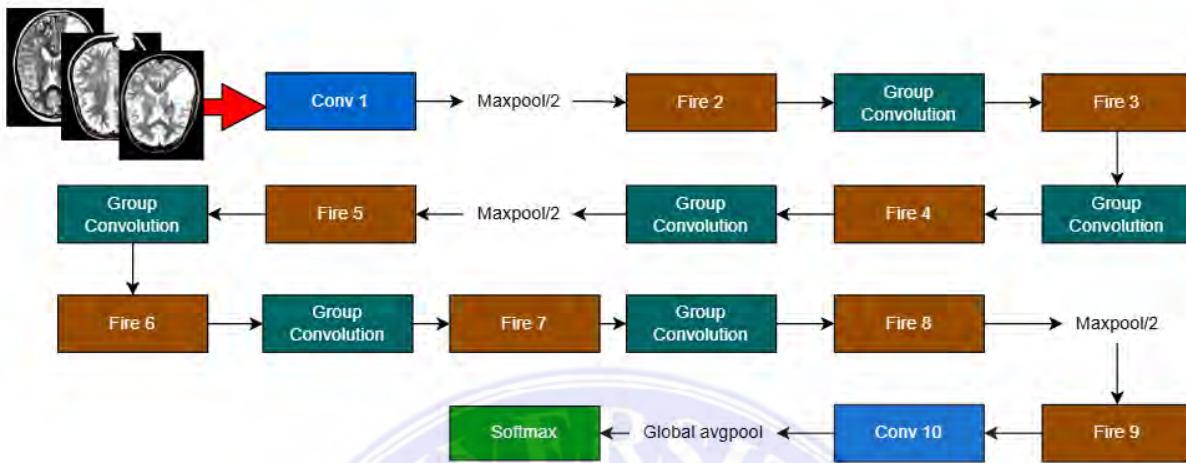


**Gambar 3 Arsitektur Group Convolution**

*Group convolution* merupakan metode dalam jaringan saraf konvolusi yang membagi *input feature map* menjadi beberapa grup, dimana masing-masing grup diproses secara terpisah menggunakan filter konvolusi khusus untuk grup tersebut (Liu et al., 2021). Pada ilustrasi, input dengan 12 *channel* dipisahkan

menjadi 3 grup (setiap grup terdiri dari 4 channel), dan masing-masing grup menghasilkan *output feature map* yang berbeda. Pendekatan ini mengurangi jumlah parameter dan beban komputasi dibandingkan dengan konvolusi konvensional, karena filter hanya bekerja pada subset *chanel* tertentu, sehingga meningkatkan efisiensi proses.

### E. Rancangan Arsitektur



Gambar 4 Rancangan Arsitektur

Gambar ini menampilkan arsitektur SqueezeNet dengan Group Convolution yang dioptimalkan untuk klasifikasi tumor otak. Model diawali dengan Conv1 untuk mengekstraksi fitur dasar, diikuti oleh Group Convolution guna meningkatkan efisiensi komputasi dengan mengurangi jumlah parameter. Selanjutnya, beberapa Fire Modules digunakan untuk mempertahankan kompleksitas fitur dengan struktur yang lebih ringan, sementara Maxpooling diterapkan untuk mengurangi dimensi data.

Arsitektur ini memiliki jalur bercabang yang memungkinkan pemrosesan fitur lebih mendalam. Group Convolution kembali diterapkan setelah Fire Module ke-8, diikuti oleh Conv10 dan Global Average Pooling untuk merangkum informasi fitur. Akhirnya, fungsi Softmax mengonversi keluaran menjadi probabilitas kelas tumor dan non-tumor. Dengan kombinasi SqueezeNet dan Group Convolution, model ini menjadi lebih ringan, efisien, dan tetap akurat dalam mendeteksi tumor otak.

### F. Evaluasi

Evaluasi model klasifikasi tumor otak berbasis SqueezeNet dengan Group Convolution dilakukan menggunakan akurasi, presisi, recall, F1-score, confusion matrix, dan ROC-AUC. Akurasi mengukur persentase prediksi benar, sementara presisi dan recall menilai keakuratan serta sensitivitas model dalam mendeteksi tumor. F1-score digunakan untuk menyeimbangkan keduanya, terutama saat terjadi ketidakseimbangan kelas. Confusion matrix memberikan analisis distribusi kesalahan prediksi, sedangkan ROC-AUC menilai kemampuan model dalam membedakan kelas positif dan negatif berdasarkan luas kurva ROC. Semakin tinggi AUC, semakin baik model dalam mengklasifikasikan tumor dan non-tumor. Kombinasi metrik ini memastikan evaluasi model yang komprehensif dan akurat.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad 1$$

$$Precision = \frac{TP}{TP + FP} \quad 2$$

$$Recall = \frac{TP}{TP + FN} \quad 3$$

$$F1 - score = 2 * \frac{\text{Recall} * \text{Precision}}{\text{Recall} + \text{Precision}}$$

### III. Hasil dan Pembahasan

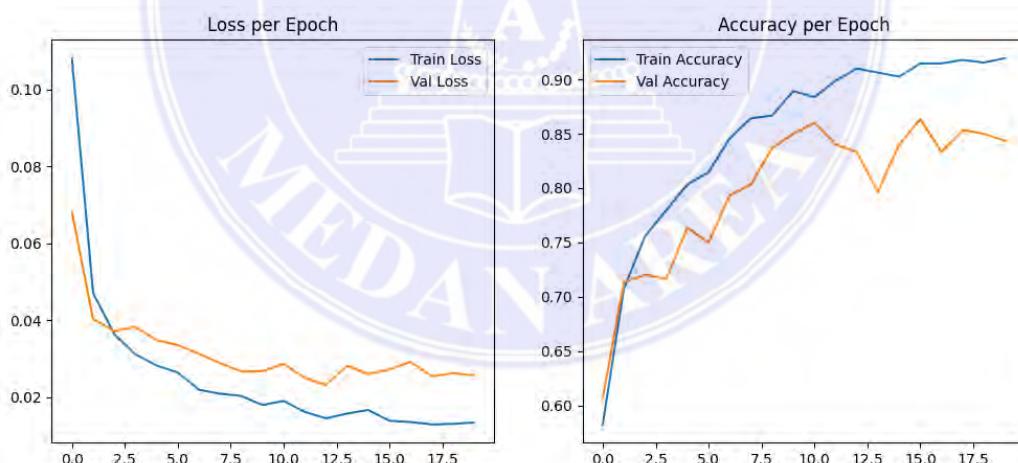
#### A. Hasil

Penelitian ini menerapkan beberapa prosedur dalam klasifikasi tumor otak menggunakan citra MRI (Magnetic Resonance Imaging). Pada tahap pemrosesan data, dataset dibagi menjadi tiga bagian utama, yaitu 80% untuk pelatihan, 10% untuk pengujian, dan 10% untuk validasi. Selanjutnya, dilakukan normalisasi data untuk mengubah variabel numerik ke dalam format yang sesuai dengan kebutuhan model, sehingga memastikan skala data seragam dan dapat diproses secara optimal oleh algoritma machine learning. Setelah tahap normalisasi, dipilih model transfer learning, yaitu SqueezeNet dengan Group Convolution, untuk meningkatkan efisiensi klasifikasi. Selain itu, dilakukan augmentasi data dengan mengubah ukuran gambar menjadi  $224 \times 224$  piksel dan  $128 \times 128$  piksel guna meningkatkan kemampuan generalisasi model. Setelah seluruh tahap tersebut selesai, proses dilanjutkan ke tahap pengujian model untuk mengevaluasi performanya dalam mendeteksi tumor otak.

Berikut merupakan evaluasi rata-rata keseluruhan model:

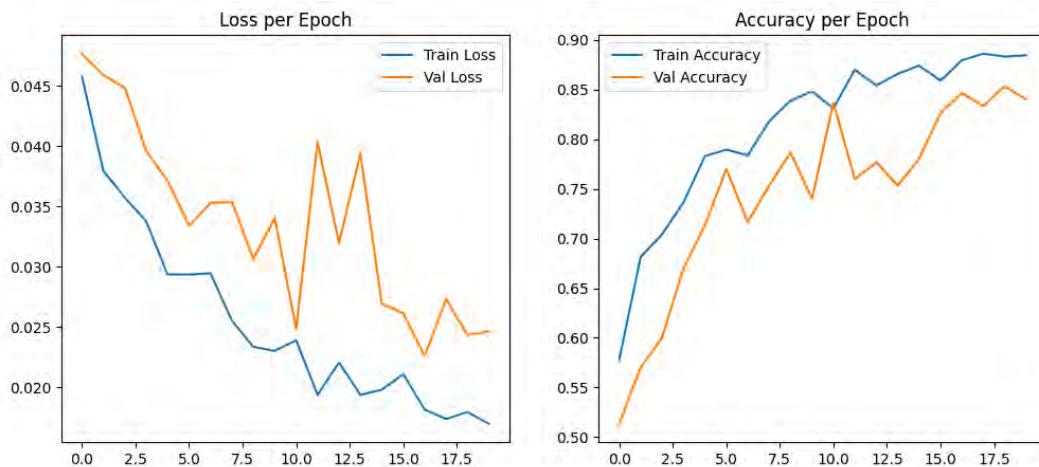
**Table 2 Evaluasi Model**

Model	Jumlah Parameter
SqueezeNet	1248424
SqueezeNet dan Group Convolution	736450

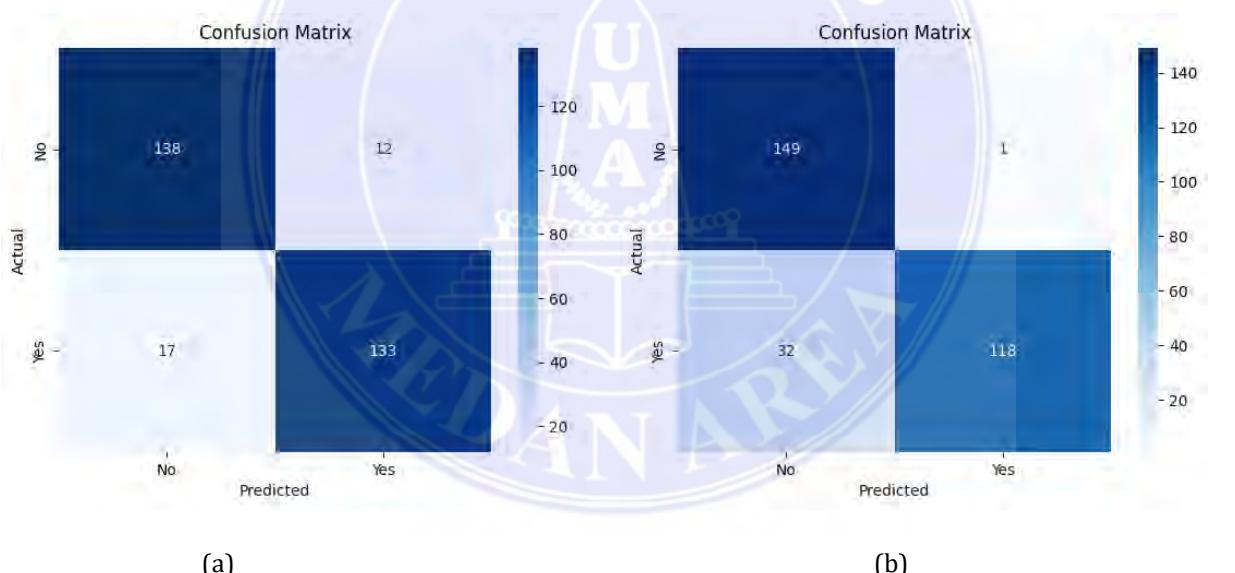


**Gambar 5 Grafik SqueezeNet**

Penurunan loss terlihat lebih fluktuatif terutama pada data validasi, meskipun tetap menunjukkan tren penurunan. Akurasi pelatihan dan validasi meningkat secara bertahap, tetapi tidak setinggi model modifikasi. Akurasi validasi berada pada kisaran 80–85%, sedikit lebih rendah dibandingkan model dengan group convolution. Hal ini menandakan bahwa model standar memiliki performa yang lebih rendah dalam proses pembelajaran dan generalisasi.

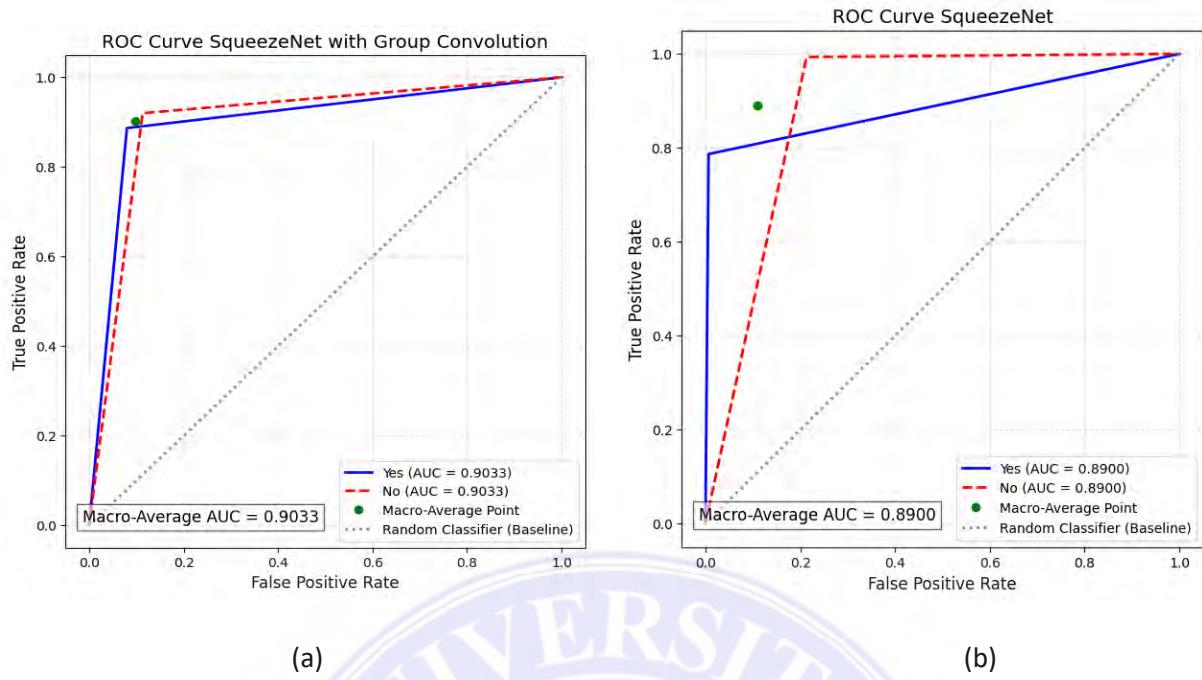
**Gambar 6 Grafik SqueezeNet dengan Group Convolution**

Gambar keenam menunjukkan grafik loss dan akurasi dari proses pelatihan dan validasi model SqueezeNet dengan group convolution selama 20 epoch. Pada grafik sebelah kiri, terlihat penurunan loss yang konsisten baik pada data pelatihan maupun validasi, yang mengindikasikan proses pembelajaran berjalan stabil. Di sisi kanan, akurasi pelatihan meningkat secara bertahap hingga mencapai lebih dari 90%, sementara akurasi validasi juga berada pada kisaran 85% dan menunjukkan kestabilan. Ini menunjukkan bahwa model tidak mengalami overfitting dan mampu melakukan generalisasi dengan baik.

**Gambar 7 Matrix (a) SqueezeNet dengan Group Convolution, (b) SqueezeNet**

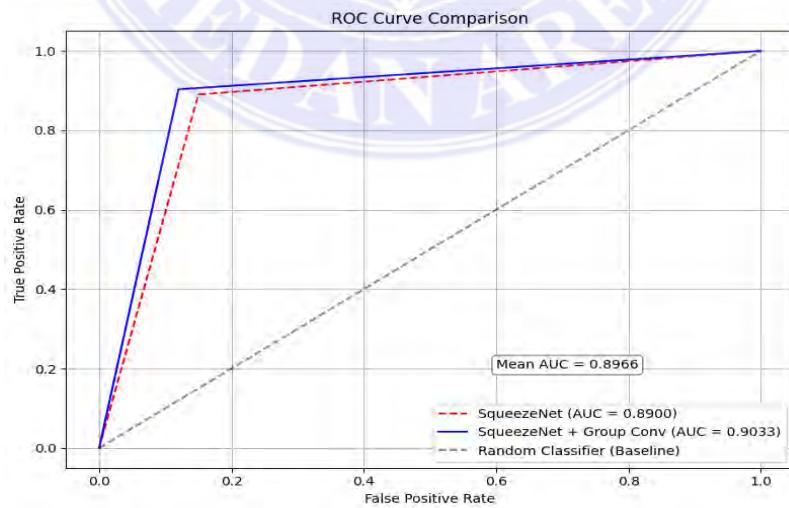
Gambar 7(a) Pada model ini, klasifikasi menjadi lebih seimbang, dengan 138 data kelas "No" dan 133 data kelas "Yes" berhasil diklasifikasikan dengan benar. Jumlah kesalahan pun menurun signifikan, masing-masing hanya 12 dan 17 untuk kelas "No" dan "Yes". Hal ini menandakan bahwa modifikasi arsitektur mampu mengurangi bias terhadap kelas tertentu, serta meningkatkan sensitivitas model terhadap deteksi kasus tumor otak (kelas "Yes").

Gambar 7(b) Berdasarkan hasil prediksi, model berhasil mengklasifikasikan 149 data kelas "No" dengan benar dan hanya satu kesalahan. Namun, pada kelas "Yes", model mengalami penurunan akurasi dengan hanya 118 prediksi yang tepat dari 150 data, serta 32 kesalahan klasifikasi sebagai "No". Ini menunjukkan bahwa model cenderung bias terhadap kelas "No", yang berpotensi membahayakan dalam konteks medis karena kasus tumor otak dapat terlewatkan akibat prediksi yang salah.

**Gambar 8 ROC AUC (a) SqueezeNet dengan Group Convolution, (b) SqueezeNet**

Gambar 8(a) Pada grafik tersebut terlihat dua kurva ROC yang mewakili kelas "Yes" dan "No", dengan masing-masing nilai AUC sebesar 0,9033. Adanya nilai AUC yang tinggi menunjukkan bahwa model mampu membedakan kedua kelas secara efektif. Titik hijau pada grafik menandakan rata-rata performa makro dari kedua kelas, yang menunjukkan keseimbangan performa model dalam mendeteksi baik kelas positif maupun negatif. Hasil ini mencerminkan keberhasilan teknik *group convolution* dalam meningkatkan kemampuan diskriminatif model.

Gambar 8(b) Nilai AUC yang dihasilkan untuk masing-masing kelas adalah 0,8900, sedikit lebih rendah dibandingkan dengan model yang dimodifikasi. Hal ini mengindikasikan bahwa meskipun performa klasifikasi model masih tergolong baik, namun kemampuan dalam membedakan antara kelas "Yes" dan "No" sedikit lebih lemah. Titik hijau sebagai indikator rata-rata makro tetap menunjukkan kinerja yang seimbang, meskipun tidak seoptimal model yang telah dimodifikasi.

**Gambar 9 Grafik ROC AUC Semua Model**

Gambar 9 menggambarkan performa dari semua model yang diuji dalam penelitian ini ROC AUC digunakan untuk menilai kemampuan model dalam membedakan antara kelas positif dan negatif di setiap model.

Berikut merupakan tabel evaluasi classification report SqueezeNet dengan Group Convolution.

**Table 3 Classification Report**

Model	Kelas	Precision	Recall	F1-Score	Support
SqueezeNet	No	0.8232	0.9933	0.9000	150
	Yes	0.9916	0.7867	0.8771	150
	Accuracy			0.8900	300
	Macro avg	0.9074	0.8900	0.8886	300
	Weighted avg	0.9074	0.8900	0.8886	300
SqueezeNet dengan Group convolution	No	0.8903	0.9200	0.9050	150
	Yes	0.9172	0.8867	0.9017	150
	Accuacy			0.9033	300
	Macro avg	0.9038	0.9034	0.9034	300
	Weighted avg	0.9038	0.9033	0.9034	300

## B. Pembahasan

Hasil evaluasi menunjukkan bahwa penerapan Group Convolution pada SqueezeNet berhasil meningkatkan keseimbangan performa klasifikasi tumor otak. Recall untuk kelas "Yes" meningkat dari 0.79 menjadi 0.89, dengan precision dan f1-score mencapai sekitar 0.90 untuk kedua kelas. Nilai macro dan weighted average juga naik dari 0.89 menjadi 0.90, menunjukkan pengurangan bias terhadap kelas tertentu dan peningkatan akurasi model secara keseluruhan.

Peningkatan ini menunjukkan bahwa Group Convolution efektif dalam mengurangi bias model terhadap kelas tertentu, sehingga meningkatkan akurasi dan keseimbangan dalam klasifikasi tumor otak.

Berikut tabel hasil perbandingan penelitian sebelumnya dengan penelitian ini.

**Table 4 Hasil Evaluasi Penelitian Sebelumnya dan Penelitian Ini**

Referensi	Model	Dataset	Akurasi	Precision	Recall	F1-Score
(Nafiiyah, 2023)	CNN	Tumor Otak: Glioma, Meningioma, No tumor, dan Pituitary	82.2%	-	-	-
(F. A. A. Harahap et al., 2023)	MobileNetV2	Tumor Otak: Glioma, Meningioma, dan Pituitary	83%	84%	84%	83%
(Hakim et al., 2023)	CNN	Tumor Otak: Normal dan Terinfeksi	85%	86%	85%	85%
Penelitian ini	SqueezeNet + Group Convolution	Tumor Otak: Normal dan Terinfeksi	90.33%	90.38%	90.34%	90.34%

## IV. SIMPULAN

Berdasarkan hasil evaluasi performa model klasifikasi tumor otak menggunakan SqueezeNet dan varian yang dimodifikasi dengan *group convolution*, dapat disimpulkan bahwa penerapan teknik *group convolution* memberikan peningkatan kinerja yang signifikan. Hal ini ditunjukkan oleh nilai AUC yang lebih tinggi (0,9033 vs 0,8900), distribusi prediksi yang lebih seimbang pada confusion matrix, serta tren peningkatan akurasi dan penurunan loss yang lebih stabil. Model dengan *group convolution* juga menunjukkan kemampuan yang lebih baik dalam mengenali kasus positif tumor otak (kelas "Yes"), yang sangat penting dalam konteks deteksi medis. Oleh karena itu, modifikasi arsitektur SqueezeNet dengan teknik *group convolution* terbukti mampu meningkatkan sensitivitas dan ketepatan klasifikasi secara keseluruhan.

UNIVERSITAS MEDAN AREA

Berdasarkan hasil evaluasi model, terdapat beberapa rekomendasi yang dapat dijadikan acuan oleh peneliti selanjutnya. Pertama, bagi peneliti yang ingin mengembangkan model klasifikasi citra medis yang ringan dan efisien, disarankan untuk menerapkan teknik group convolution pada arsitektur seperti SqueezeNet. Teknik ini terbukti dapat meningkatkan kinerja model tanpa menambah kompleksitas komputasi yang signifikan. Kedua, untuk meningkatkan kemampuan model dalam mengenali fitur-fitur penting pada citra, terutama pada kelas minoritas seperti tumor otak, peneliti disarankan untuk mengintegrasikan mekanisme attention seperti SE-Block atau CBAM agar jaringan dapat lebih fokus pada bagian penting dari gambar.

## DAFTAR PUSTAKA

- Aamir, M., Rahman, Z., Dayo, Z. A., Abro, W. A., Uddin, M. I., Khan, I., Imran, A. S., Ali, Z., Ishfaq, M., Guan, Y., & Hu, Z. (2022). A deep learning approach for brain tumor classification using MRI images. *Computers and Electrical Engineering*, 101, 108105.  
<https://doi.org/https://doi.org/10.1016/j.compeleceng.2022.108105>
- Agrawal, P., Katal, N., & Hooda, N. (2022). Segmentation and classification of brain tumor using 3D-UNet deep neural networks. *International Journal of Cognitive Computing in Engineering*, 3(November), 199–210. <https://doi.org/10.1016/j.ijcce.2022.11.001>
- Ayu, D. W., & Pradipta, G. A. (2024). SqueezeNet Feature Extraction dan Gradient Boosting untuk Klasifikasi Penyakit Monkeypox pada Citra Kulit. *Jurnal Sistem Dan Informatika (JSI)*, 18(2), 177–183.  
<https://doi.org/10.30864/jsi.v18i2.612>
- Ekong, F., Yu, Y., Patamia, R. A., Feng, X., Tang, Q., Mazumder, P., & Cai, J. (2022). Bayesian Depth-Wise Convolutional Neural Network Design for Brain Tumor MRI Classification. *Diagnostics*, 12(7), 1–17.  
<https://doi.org/10.3390/diagnostics12071657>
- Febrianti, A. S., Sardjono, T. A., & Babgei, A. F. (2020). Klasifikasi Tumor Otak pada Citra Magnetic Resonance Image dengan Menggunakan Metode Support Vector Machine. *Jurnal Teknik ITS*, 9(1).  
<https://doi.org/10.12962/j23373539.v9i1.51587>
- Gupta, S. R. (2022). Prediction time of breast cancer tumor recurrence using Machine Learning. *Cancer Treatment and Research Communications*, 32(July), 100602.  
<https://doi.org/10.1016/j.ctarc.2022.100602>
- Hakim, M. N. M., Nugroho, A. B., & Minarno, A. E. (2023). Prediksi Tumor Otak Menggunakan Metode Convolutional Neural Network. *Informatika Mulawarman : Jurnal Ilmiah Ilmu Komputer*, 17(1), 48.  
<https://doi.org/10.30872/jim.v17i1.5246>
- Hao, M., Sun, Q., Xuan, C., Zhang, X., & Zhao, M. (2024). SqueezeNet: An Improved Lightweight Neural Network for Sheep Facial Recognition. *Applied Sciences (Switzerland)*, 14(4), 1–13.  
<https://doi.org/10.3390/app14041399>
- Harahap, F. A. A., Nafisa, A. N., Purba, E. N. D. B., & Putri, N. A. (2023). Implementasi Algoritma Convolutional Neural Network Arsitektur Model Mobilenetv2 Dalam Klasifikasi Penyakit Tumor Otak Glioma, Pituitary Dan Meningioma. *Jurnal Teknologi Informasi, Komputer, Dan Aplikasinya (JTIKA)*, 5(1), 53–61. <https://doi.org/10.29303/jtika.v5i1.234>
- Harahap, H., Rahman, S., & Zen, M. (2024). Analisis Existing Convolutional Neural Network Untuk Klasifikasi Usia Pengunjung Rumah Sakit: Studi Kasus Pemantauan Anak dan Dewasa. *Journal of Computer Science and Information Technology E-ISSN*, 4(1), 16.
- Jeri, & Hidayat, Z. S. (2024). Penentuan Ukuran Batch Optimal Untuk Pelatihan YOLOV8 Dalam Pendekripsi Objek Pada Kendaraan Otomotif. *Jurnal Ilmiah NERO*, 9(1), 35–48.

- Jose, J. A., Kumar, C. S., & Sureshkumar, S. (2022). Tuna classification using super learner ensemble of region-based CNN-grouped 2D-LBP models. *Information Processing in Agriculture*, 9(1), 68–79. <https://doi.org/10.1016/j.inpa.2021.01.001>
- Liu, H., Li, Q., & Wang, I. C. (2021). A deep-learning model with learnable group convolution and deep supervision for brain tumor segmentation. *Mathematical Problems in Engineering*, 2021, 1–11. <https://doi.org/10.1155/2021/6661083>
- Lyu, Z., Yu, T., Pan, F., Zhang, Y., Luo, J., Zhang, D., Chen, Y., Zhang, B., & Li, G. (2024). A survey of model compression strategies for object detection. In *Multimedia Tools and Applications* (Vol. 83, Issue 16). Springer US. <https://doi.org/10.1007/s11042-023-17192-x>
- Nafiiyah, N. (2023). Identifikasi Tumor Otak Citra MRI dengan Convolutional Neural Network. *Jurnal Informatika: Jurnal Pengembangan IT*, 8(3), 213–219. <https://doi.org/10.30591/jpit.v8i3.4985>
- Ningrum, A. P., Winarno, S., & Praskatama, V. (2024). Klasifikasi Kualitas Biji Kedelai Menggunakan Transfer Learning Convolutional Neural Network Dan SMOTE. *JOURNAL OF APPLIED COMPUTER SCIENCE AND TECHNOLOGY (JACOST)*, 5(2), 155–164.
- Pangestu, A., Purnama, B., & Risnandar, R. (2024). Vision Transformer untuk Klasifikasi Kematangan Pisang. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 11(1), 75–84. <https://doi.org/10.25126/jtiik.20241117389>
- Putri, I., Nurliani, S., Irhanda, L. A., Wulandari, L., & Supiyandi. (2024). Penggunaan Visi Komputer Untuk Deteksi Masker Wajah Pada Lingkungan Publik Menggunakan CNN. *Jurnal Ilmiah Multidisiplin*, 2(11), 649–655.
- Sa'idadah, S., Suparta, I. P. Y. N., & Suhartono, E. (2022). Modifikasi Convolutional Neural Network Arsitektur GoogLeNet dengan Dull Razor Filtering untuk Klasifikasi Kanker Kulit. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 11(2), 148–153. <https://doi.org/10.22146/jnteti.v11i2.2739>
- Simanjorang, R. M., Sitohang, A., Sembiring, A., & Simanjorang, S. (2025). Implementasi Jaringan Syaraf Tiruan Dalam Klasifikasi Citra Medis. *Jurnal SAINTIKOM (Jurnal Sains Manajemen Informatika Dan Komputer)*, 24, 64–72.
- Situmorang, B. H., & Asri, Y. (2024). Identifikasi Kematangan Buah Menggunakan Teknik Deep Learning. *KILAT*, 13(1), 11–19.
- Su, Z., Fang, L., Kang, W., Hu, D., Pietikäinen, M., & Liu, L. (2020). Dynamic Group Convolution for Accelerating Convolutional Neural Networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12351 LNCS, 138–155. [https://doi.org/10.1007/978-3-030-58539-6\\_9](https://doi.org/10.1007/978-3-030-58539-6_9)
- Thaariq, M. A., Baskara, M. D. M., Chaniago, R. A., Christin, D., & Ernawati, I. (2024). Systematic Literature Review : Analisis Penerapan. *Seminar Nasional Mahasiswa Ilmu Komputer Dan Aplikasinya (SENAMIKA)*, April, 168–173.
- Togatorop, P. R., & Fauzi, A. (2022). Klasifikasi Penggunaan Masker Wajah Menggunakan SqueezeNet. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 9(1), 397–406. <https://doi.org/10.35957/jatisi.v9i1.642>
- Wang, X., Kan, M., Shan, S., & Chen, X. (2019). Fully learnable group convolution for acceleration of deep neural networks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2019-June, 9041–9050. <https://doi.org/10.1109/CVPR.2019.00926>